

ПРИМЕНЕНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ПРОЕКТИРОВАНИИ ЦИКЛОТРОНОВ

*О. В. Карамышев^{a, 1}, И. Д. Ляпин^a,
Т. В. Карамышева^a, М. А. Шуравин^a*

^a Объединенный институт ядерных исследований, Дубна, Россия

При разработке циклотрона требуется проведение большого количества расчетов как отдельных систем ускорителя, так и динамики движения частиц. Искусственный интеллект может способствовать увеличению скорости проведения расчетов, оптимизировать применяемые для расчетов коды, улучшить качество получаемых результатов. Представлены первые результаты применения машинного обучения для формирования магнитного поля, проанализированы возможности использования компьютерного зрения и перспективы применения искусственного интеллекта для оптимизации движения пучка.

In cyclotron development, a large number of calculations are required for both individual accelerator systems and particle motion dynamics. Artificial intelligence can contribute to increasing the speed of calculations, optimizing the codes used and improving the quality of the results obtained. The initial results of using machine learning for magnetic field formation are presented, and the potential applications of computer vision and AI prospects for optimizing beam motion are analyzed.

PACS: 29.20.dg

ВВЕДЕНИЕ

Искусственный интеллект (ИИ) уже прочно вошел в нашу повседневную жизнь и находит применение в самых разнообразных сферах. На практике ИИ используется для распознавания лиц на устройствах, таких как смартфоны и системы безопасности, а также для автоматического перевода текстов и транскрибирования голосовых сообщений.

Значимость применения ИИ в науке трудно переоценить, особенно в тех областях, где требуется обработка больших объемов данных. Наиболее перспективные направления научного использования ИИ:

- **Медицина:** анализ геномных данных, моделирование биологических процессов, диагностика заболеваний, обработка медицинских изображений и разработка новых лекарств.

¹E-mail: olegka@jinr.ru

- **Климатология:** моделирование климатических изменений, анализ экологических данных.
- **Физика и химия:** моделирование сложных физических процессов, создание новых материалов.
- **Астрономия:** анализ данных о космосе и работа с телескопическими изображениями.

Прежде чем рассматривать применение ИИ в проектировании циклотронов, важно понять основные термины. ИИ — это широкое понятие, включающее алгоритмы, которые позволяют машинам выполнять когнитивные функции, такие как решение задач, рассуждение и обучение.

Технологии и методы работы с моделями ИИ (Artificial intelligence, AI) объединяются под термином машинное обучение (Machine learning, ML), подразделом которого является глубинное обучение (Deep learning, DL). Предметом изучения DL являются искусственные нейронные сети (Artificial neural networks, ANN).

Классические подходы в машинном обучении позволяют алгоритмам обучаться на структурированных данных, выявляя закономерности, и эффективно решать поставленные задачи. Для анализа неструктурированных данных, таких как изображения, звук и обработка естественного языка, требуются более сложные алгоритмы. Нейронные сети имитируют работу нейронов человеческого мозга и способны генерировать прогнозы и решения. Увеличение количества слоев, усложнение архитектуры и предоставление большего объема качественных данных приводит к улучшению результатов.

С ростом сложности задач, решаемых с помощью ИИ, возрастают и потребности в вычислительных мощностях. Основные требования включают использование графических или тензорных процессоров, доступ к большим объемам памяти и возможность масштабирования вычислительных систем. Развитие ИИ стимулирует и развитие технологий, таких как квантовые вычисления и более эффективные алгоритмы. Однако обучение крупных моделей и анализ данных требуют значительных вычислительных и энергетических затрат. В ОИЯИ созданы все условия для применения ИИ в науке: современные вычислительные мощности ЛИТ и развитая энергетическая инфраструктура России позволяют использовать передовые методы ИИ для научных исследований.

ЦИКЛОТРОНЫ И ИХ ПРИМЕНЕНИЕ

Циклотроны — это тип ускорителей частиц, широко применяемых в таких областях, как ядерная медицина, материаловедение и фундаментальные исследования в физике. В последние годы наблюдается стремительный рост числа циклотронов, предназначенных для производства медицинских радиоизотопов и протонной терапии (рис. 1).

Графики были дополнены до 2023 г. информацией из [2].

Увеличение спроса на циклотроны усиливает конкуренцию между производителями и подчеркивает важность поиска оптимальных компоновок циклотронов для нужд радиомедицины, охватывающих диапазон энергий от 10 до 230 МэВ.

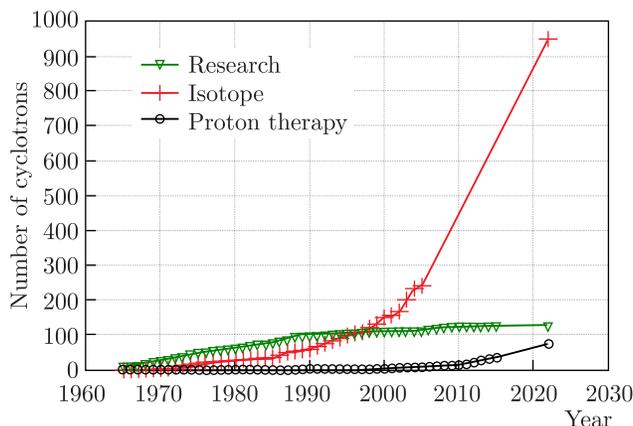


Рис. 1 (цветной в электронной версии). Динамика роста количества циклотронов в мире по годам. Зеленые треугольники показывают число циклотронов, работающих в исследовательских центрах, красные крестики — количество циклотронов, используемых для производства медицинских радиоизотопов, черные кружки — число циклотронов, применяемых для протонной терапии [1]

Большинство медицинских циклотронов построено по стандартной схеме, которая стала «золотым стандартом» в отрасли: 4 сектора и 2 (иногда 4) резонатора. Но существуют ли альтернативные решения? Множество интересных идей было предложено и протестировано, и сейчас необходимо объединить лучшие из них в одном оптимальном устройстве. Проектирование и оптимизация таких сложных систем, как циклотроны, требует тщательного учета множества взаимосвязанных параметров. Постоянно ведутся исследования и поиск методов для разработки более эффективных систем циклотронов с целью улучшения их характеристик и повышения производительности ускорителя.

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В ПРОЕКТИРОВАНИИ И ОПТИМИЗАЦИИ ЦИКЛОТРОНОВ: ОБЗОР ЛИТЕРАТУРЫ

Ниже представлен краткий обзор применений ИИ для проектирования и управления циклотронами, которые удалось найти в открытой печати за последние годы. Применением ИИ в ускорительной физике заинтересовались специалисты в различных типах ускорителей. Появился ряд статей о самых разных применениях ИИ, например, в работах [3, 4] описано применение ИИ в управлении синхротроном. Нас интересовало, в первую очередь, применение ИИ для проектирования циклотронов, однако, помимо этапа проектирования, ИИ также может сыграть важную роль в управлении, эксплуатации и обслуживании циклотронов. Анализируя данные с датчиков и рабочие журналы, видим, что системы на основе ИИ могут обнаруживать аномалии, предсказывать потенциальные отказы и рекомендовать профилактические меры.

Одной из ключевых областей, где ИИ может внести значительный вклад в проектирование циклотронов, является моделирование и симуляция динамики пучка частиц. Динамика пучка имеет решающее значение для работы циклотронов, поскольку от нее зависят эффективность прохождения пучка и его интенсивность. Модели на основе ИИ можно обучить на больших наборах экспериментальных и расчетных данных для точного прогнозирования поведения пучков частиц, что позволит более эффективно оптимизировать параметры устройства.

Кроме того, ИИ может применяться для оптимизации отдельных компонентов циклотронов, таких как магнитная система, ускоряющие резонаторы и система вывода пучка. Используя алгоритмы машинного обучения, исследователи могут анализировать огромное количество возможных конструкций и выявлять те конфигурации, которые не только максимизируют производительность циклотронов, но и снижают энергопотребление и повышают надежность.

Используя алгоритмы ИИ, исследователи могут анализировать огромные объемы данных, выявлять закономерности и оптимизировать проектирование циклотронов более эффективно, чем при традиционных ручных методах.

СИСТЕМЫ УПРАВЛЕНИЯ

Одной из ключевых областей применения ИИ в циклотронах является оптимизация систем управления. Алгоритмы на основе ИИ могут использоваться для точной настройки параметров различных компонентов циклотронов, таких как магнитное поле, энергия пучка и механизмы вывода, для достижения оптимальной производительности и стабильности.

В работе [5] представлен новый подход, использующий искусственные нейронные сети для предсказуемого управления ионным источником в циклотроне RFT-30, что подчеркивает трансформационный потенциал ИИ в технологии ускорителей.

Кроме усовершенствований в области предсказуемого управления, потенциал решений на основе ИИ простирается далеко за пределы оптимизации ионных источников. Они могут значительно улучшить механизмы обнаружения и восстановления неисправностей в ускорителях частиц. Например, интеграция сложных алгоритмов машинного обучения может обеспечить мониторинг производительности системы в реальном времени, позволяя немедленно выявлять несоответствия, которые могут указывать на неисправности или неэффективность. Такой проактивный подход не только минимизирует время простоя, но и снижает необходимость в интенсивном ручном контроле, традиционно требуемом при запуске ускорителей после технического обслуживания или непредвиденных сбоев.

Кроме того, благодаря применению комбинации искусственных нейронных сетей и продвинутой аналитики данных, операторы могут разработать более надежные модели, способные симулировать различные операционные сценарии, что улучшает общую устойчивость системы и ее адаптивность в динамичных научных средах. Такие инновации подчеркивают трансформационное влияние ИИ на будущее технологий ускорителей, открывая путь к расширенным экспериментальным возможностям и увеличению производительности в научных исследованиях.

В области адронной терапии, которая использует заряженные частицы, такие как протоны или ионы углерода для лечения рака, недавние достижения в ИИ [6] также показали свою эффективность в повышении точности и эффективности процесса лечения.

ПРОЕКТИРОВАНИЕ РЕЗОНАТОРОВ ВЧ

Помимо систем управления, вычислительные методы на основе искусственного интеллекта также показали свою полезность в оптимизации ВЧ-резонаторов, которые являются критическим компонентом в проектировании циклотронов. Благодаря использованию продвинутых алгоритмов машинного обучения, исследователи смогли более эффективно анализировать сложное пространство параметров проектирования, что привело к открытию новых геометрий резонаторов, превосходящих традиционные конструкции по эффективности и качеству пучка.

В статье [7] описывается значимость циклотрона IganCYC10, который является 10-МэВ циклотроном с азимутально переменным полем (AVF), разработанным для различных применений, включая производство изотопов, ядерные реакции и медицинские исследования в области ядерной спектроскопии. Циклотрон ускоряет протоны до различных энергий с помощью двух резонаторов. Заряженные частицы производятся внутренним источником ионов. Статья подчеркивает сложность моделирования резонатора циклотронов, который включает в себя различные параметры, влияющие на его производительность, такие как диаметр и зазор тунера-диска. Авторы отмечают необходимость эффективного подхода к моделированию для понимания взаимосвязей между этими параметрами и желаемыми результатами, в частности резонансной частотой и параметрами рассеяния, такими как S11.

Для решения этой задачи в статье предлагается использование прямой нейронной сети (FNN), обученной с оптимизированным алгоритмом обратного распространения (BP). Авторы стремятся показать, что этот подход может точно оценивать параметры проектирования резонатора циклотронов без необходимости длительных симуляций, которые обычно требуются.

ДИНАМИКА ПУЧКА

В тексте статей [8,9] описывается новый подход, использующий машинное обучение (ML) для создания суррогатных моделей на основе редких данных физического моделирования, что позволяет быстро и точно представлять динамику пучка в ускорителях частиц. Эти модели на основе ML могут быстро предсказывать параметры пучка с точностью, сопоставимой с физическими симуляциями, что помогает в многокритериальной оптимизации, планировании экспериментов и оперативной оптимизации в ходе работы ускорителя. Использование машинного обучения в этом контексте представляет собой значительный прогресс в оптимизации производительности ускорителей и упрощении процесса проектирования, предлагая перспективное направление для повышения возможностей систем ускорителей частиц. Принцип работы ML для расчета динамики пучка подробно описан в статье [10] и изображен на схеме рис. 2.

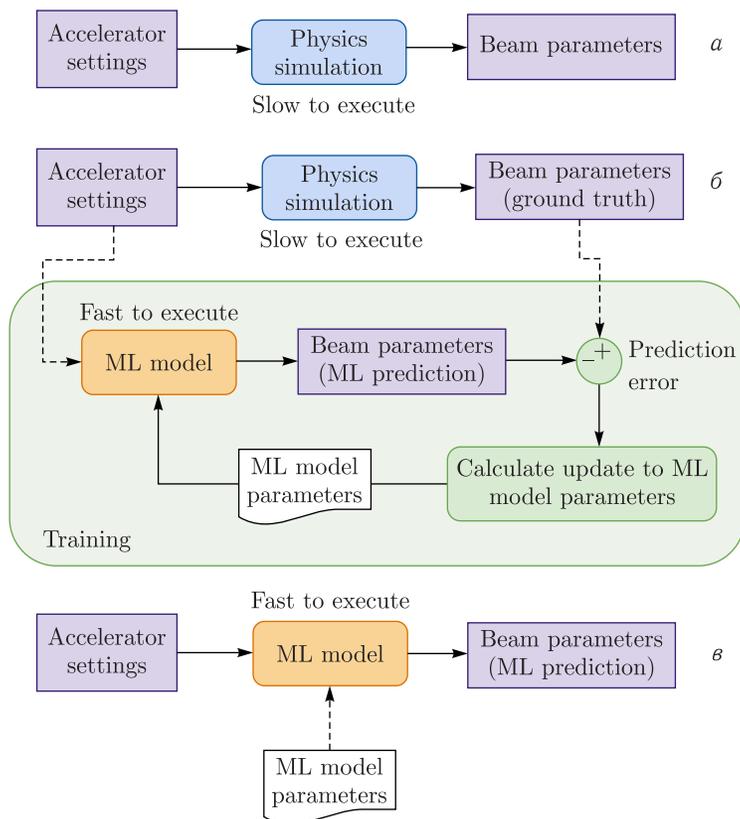


Рис. 2. Симуляция, требующая больших вычислительных ресурсов (а). Мы используем эту физическую симуляцию для создания набора обучающих данных для модели машинного обучения, охватывающего широкий диапазон входных параметров. Параметры модели машинного обучения оптимизируются до тех пор, пока предсказания параметров пучка не начнут совпадать с результатами физической симуляции (б). Результатом является быстро исполняемая модель физической симуляции, которая может использоваться для оптимизации и моделирования (в) [10]

Кроме того, авторы подчеркивают потенциал обновления этих моделей на основе ML с использованием фактических измерений на ускорителе, что позволит улучшить их точность и соответствие реальному поведению ускорителя.

ПРИМЕНЕНИЯ В РАЗРАБОТКЕ ЦИКЛОТРОНА MSC230

Изохронизация карты магнитного поля. При проектировании циклотрона одной из ключевых задач является расчетное формирование магнитного поля. В медицинских циклотронах требуемое магнитное поле обычно формируется за счет конфигурации полюсов магнита. Важно обеспечить стабильность движения пучка, которая достигается поперечной устойчивостью и синхронизацией ускорения с фиксирован-

ной частотой ускоряющей системы (требуется изохронное магнитное поле). Для достижения изохронизма в одном варианте магнитной системы необходимо выполнить около десяти итераций изменений кривой ширины сектора. В случае циклотрона MSC230 [12] было рассмотрено несколько сотен таких вариантов, поскольку любое изменение в расположении катушек, размерах криостата и других компонентов влечет за собой необходимость заново изохронизировать магнитное поле.

Функция отклика. Одним из методов, который позволяет избежать ручной подстройки ширины сектора на каждом радиусе, является расчет на основе функции отклика. Для этого сначала рассчитывается магнитное поле для двух моделей, отличающихся по угловой ширине сектора на фиксированную величину, например, на 1° для каждого радиуса. Формула отклика выглядит следующим образом:

$$F_{\text{resp}} = \frac{\Delta f(r)}{\Delta w(r)}.$$

Таким образом, можно определить отклик системы — изменение частоты обращения частиц в зависимости от изменения ширины сектора (рис. 3). Этот метод позволяет быстрее и точнее настроить параметры циклотронов, минимизируя ручную работу.

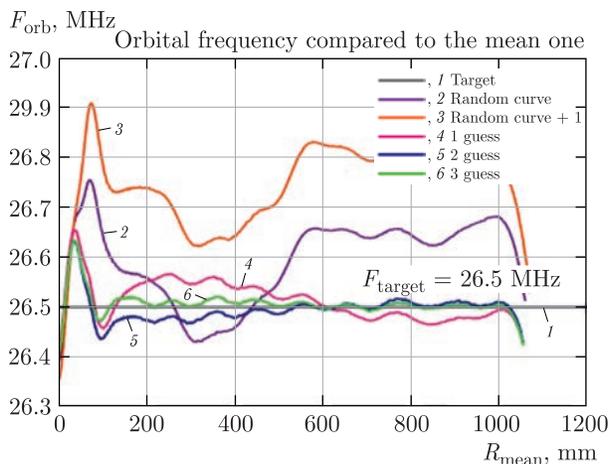


Рис. 3. Процесс изохронизации методом функции отклика

Постановка задачи машинного обучения для изохронизации магнитного поля. Накопленные данные по геометрии и распределению магнитного поля можно использовать для обучения модели машинного обучения. Первые варианты сравнения между моделью, основанной на ML, и методом функции отклика показали, что обучение может значительно сократить время, необходимое для изохронизации.

Для обучения алгоритмов были выбраны десятки пар данных, включающих кривые ширины сектора и рассчитанные частоты в зависимости от радиуса. При этом физическая модель магнита неоднократно изменялась: варьировались размеры криостата, ток катушки и другие параметры. Таким образом, собранные данные отличались не только по ширине секторов.

К сожалению, для того чтобы напрямую предсказывать изохронную кривую ширины сектора, имеющихся данных оказалось явно недостаточно. Поэтому задачу решили переформулировать: алгоритму предложили предсказывать изменение частоты от радиуса по изменению угловой ширины от радиуса, что представляет собой своего рода аналог функции отклика, но более сложный. Это позволило, имея семь расчетов для одной физической модели магнита, составить 21 пару графиков, где фиксировались изменения ширины сектора и соответствующие им изменения частоты. При этом расчеты в каждой паре можно было менять местами, получая обратные по знаку результаты, что также использовалось для обучения модели.

Признаки рассчитывались для каждой пары графиков с интервалом в 10 мм по радиусу, таким образом, для обучения алгоритма было собрано более 50 000 образцов. В итоге мы получили обычную задачу регрессии: для каждого радиуса мы предсказываем одно число – изменение частоты. При такой постановке задачи мы получили достаточное количество данных для обучения модели.

Обучение математической модели. Были рассчитаны следующие признаки для модели:

1. Результирующее изменение частоты (res) — отражает итоговое изменение частоты частицы на рассматриваемом радиусе.

2. Изменение ширины сектора на радиусах, смещенных от заданного на 0, 5, 10, 20, 200 и 1000 мм в обе стороны — обозначаются как $wdXX$ (для смещений в положительную сторону) и $wd - XX$ (для смещений в отрицательную сторону). Эти значения показывают, как изменяется ширина сектора в зависимости от удаления от исходного радиуса.

3. Средние значения изменения ширины сектора между смежными точками (mean_wd_XX_YY) — вычисляются для интервалов между различными радиусами. Эти средние значения помогают сгладить локальные изменения и более точно оценить поведение ширины сектора.

4. Разница между частотами для первого расчета на радиусах 0, 7, 20 и 50 мм (fr_dXX) — этот параметр фиксирует разницу в частотах, но использует только одну из частотных кривых, поэтому напрямую не связан с результирующими значениями частоты.

Для решения данной задачи был выбран алгоритм CatBoost — реализация градиентного бустинга на деревьях решений, разработанный компанией Яндекс. В качестве обучающего набора использовались 30 000 образцов, около 20 000 были выделены для тестирования. Это соотношение было обусловлено тем, что при переносе одного расчета в тестовую выборку туда же попадают все его комбинации, использованные в других образцах.

Чтобы избежать переобучения, процесс обучения был остановлен, как только улучшение результатов на тестовой выборке прекратилось.

На рис. 4 представлены первые 10 признаков, отсортированных по убыванию их важности. Как и ожидалось, на первых двух местах находятся название физической модели и изменение ширины сектора на соответствующем радиусе.

Результаты. Для оценки работы разработанного алгоритма были проведены два теста на новой физической модели с измененным ярмом и током катушки. Первый тест был выполнен с использованием метода функции отклика, результаты которого

	Feature	Importance
2	model_name	14.043936
1	wd0	14.009209
15	mean_wd_200_1000	13.312181
13	mean_wd_20_200	9.678120
8	fr_d150	6.021971
4	wd20	5.214260
14	mean_wd_-200_-20	3.859361
3	wd10	3.428996
11	mean_wd_10_20	3.248552
18	wd-20	3.171732

Рис. 4. Признаки в порядке убывания важности

представлены на рис. 4. Второй тест проводился с использованием созданной математической модели.

Сначала был выполнен базовый расчет (random curve), аналогичный тому, который применяется в методе функции отклика. Затем проведена оптимизация кривой ширины сектора. Для каждого нового значения ширины с шагом по радиусу в 1 мм модель предсказывала изменения частоты. На каждом этапе вычислялась среднеквадратичная ошибка (MSE) частоты относительно целевого значения в диапазоне радиусов изохронного поля. Оптимизация осуществлялась методом градиентного спуска и занимала порядка 1–2 мин.

Таким образом, использование математической модели позволяет предсказать изменения частоты с новой кривой всего за доли секунды, тогда как традиционные расчеты занимают порядка 1 ч.

На рис. 5 представлен результат изохронизации с применением методов машинного обучения. Для оптимизации был использован всего один предварительный расчет (в отличие от двух в методе функции отклика), после чего проведены две итерации (рис. 6). В итоге удалось достичь улучшенного результата, выполнив всего три расчета вместо пяти.

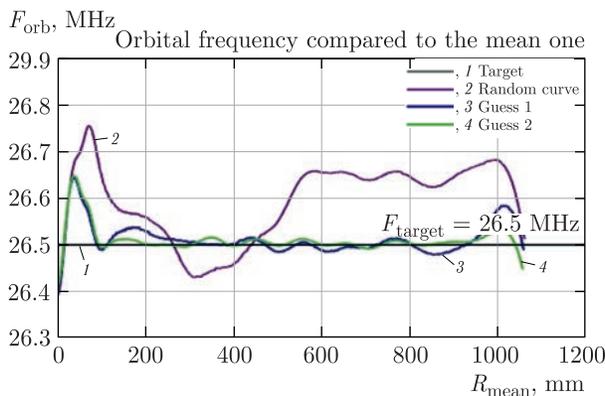


Рис. 5. Процесс изохронизации с использованием машинного обучения

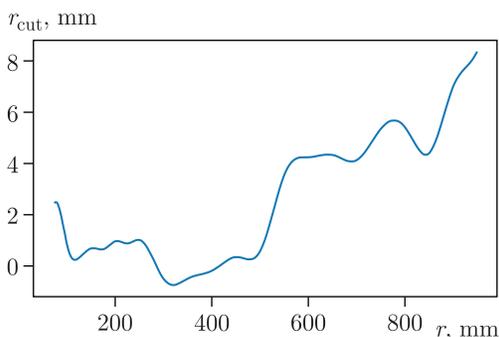


Рис. 6. Разница между первоначальной шириной сектора и шириной после второй итерации, полученной с использованием машинного обучения

Таблица 1. Среднеквадратичная ошибка от целевой частоты

Расчет, итерация	Функция отклика	Машинное обучение
Предварительный расчет 1	132	132
Предварительный расчет 2	653	—
Итерация 1	12	2
Итерация 2	3,6	0,7
Итерация 3	0,86	—

Сравнение среднеквадратичных ошибок для нескольких итераций обоих методов показано в табл. 1.

С увеличением объема данных для обучения точность данной математической модели будет улучшаться.

Эту модель планируется использовать и на этапе пусконаладочных работ для реального формирования магнитного поля. Преимущество модели заключается в том, что, имея только одну карту поля, она может достаточно точно предсказать необходимые изменения ширины сектора. При формировании поля будут использовать измеренную карту поля.

ПРИМЕНЕНИЕ МЕТОДОВ КОМПЬЮТЕРНОГО ЗРЕНИЯ ДЛЯ УЛУЧШЕНИЯ КАЧЕСТВА КАРТЫ МАГНИТНОГО ПОЛЯ ЦИКЛОТРОНА

При создании циклотрона важной задачей является формирование магнитного поля, способного обеспечить эффективное ускорение пучка. Для этой цели приходится анализировать карты магнитного поля с целью последующей корректировки магнита для придания требуемых характеристик. Карта магнитного поля представляет собой матрицу распределенных значений индукции магнитного поля в медианной плоскости циклотрона. Процедура измерений карты магнитного поля — длительный процесс, существенно зависящий от количества точек измерения. Целью работы является поиск методики, позволяющей получить улучшенную карту магнитного поля, при небольшом количестве измерений, качество которой будет выше, чем при использовании бикубической интерполяции.

Обучение моделей. Обучение моделей осуществлялось с использованием рассчитанных карт магнитного поля на сетках с мелким и крупным шагом (видно отличие по разрешению на рисунках внизу).

Цель: имея карту, аналогичную карте (рис. 7), расположенной слева (LR), получить более качественную карту, как на рисунке справа (HR)

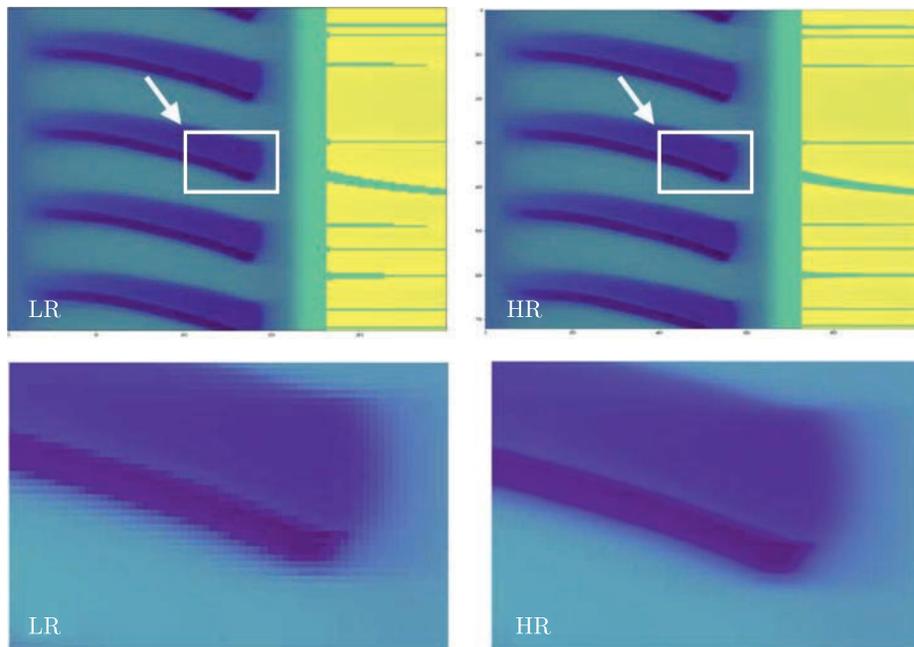


Рис. 7. Визуальное представление карт магнитного поля

При проведении экспериментов рассматривались методы и модели: бикубическая интерполяция, VDSR, SRGAN, ESRGAN, Real-ESRGAN, SR3, Stable Diffusion, SwinIR.

Результаты. Был проведен сравнительный анализ метода бикубической интерполяции и методов повышения качества измеренных карт магнитного поля, основанных на нейросетевом подходе, а именно суперразрешении (SISR, Single Image Super-Resolution).

Качество полученных результатов оценивалось с использованием метрик: 1) PSNR (peak signal-to-noise ratio — пиковое отношение сигнала к шуму dB) и 2) SSIM (structural similarity index measure — индекс структурного сходства).

$$\text{PSNR} = 10 \log_{10} \left(\frac{L^2}{\text{MSE}} \right), \quad (1)$$

где L — максимальное значение, принимаемое пикселем изображения. В нашем случае это значение равно 255.

$$\text{SSIM}(A, \hat{A}) = \frac{(2\mu_A \mu_{\hat{A}} + C_1)(\sigma_{A\hat{A}} + C_2)}{(\mu_A^2 + \mu_{\hat{A}}^2 + C_1)(\sigma_A^2 + \sigma_{\hat{A}}^2 + C_2)}, \quad (2)$$

где A — изображение высокого качества; \hat{A} — восстановленное изображение; μ_A — среднее A ; $\mu_{\hat{A}}$ — среднее \hat{A} ; σ_A — дисперсия A ; $\sigma_{\hat{A}}$ — дисперсия \hat{A} ; $\sigma_{A\hat{A}}$ — ковариация между A и \hat{A} ; C_1 и C_2 — константы, позволяющие избежать нестабильность.

Полученные результаты (табл. 2) продемонстрировали превосходство моделей, построенных на основе архитектур генеративно-состязательных сетей (GAN), в частности Real-ESRGAN [16], а также трансформерной архитектуры SwinIR [17] и сверточной архитектуры VDSR [18] по сравнению с методом бикубической интерполяции.

Таблица 2. Результаты и параметры проведенных экспериментов

Method	Training time	Num epochs	Weights used	Comments	PSNR, dB	SSIM
Bicubic	—	—	—	—	37.573590	0.989502
SRGAN	3 h	20 k	Pre-trained	Unofficial Sgrvinod implementation	34.672982	0.968103
ESRGAN	6 h	400 k	Pre-trained	Official implementation	49.711051	0.996742
Real-ESRGAN	6 h	400 k	Pre-trained	Official implementation	53.765625	0.997906
SR3	6 h	500 k	Pre-trained	Unofficial Janspiry implementation	28.608477	0.968259
Stable diffusion	—	—	Zero-shot	Version 2.1. official x4-upscaler	34.036395	0.972982
VDSR	1.5 h	100 k	Pre-trained	Unofficial Lornatang implementation	49.724477	0.996429
SwinIR	~ 4 h	50 k	Pre-trained	Official implementation, task: classical SR	50.363990	0.997275

Лучшими моделями для решения поставленной задачи можно считать Real-ESRGAN, SwinIR, VDSR. Real-ESRGAN показала наивысшее качество, но обучение проходит достаточно длительно и требует видеокарты высокой производительности. SwinIR показывает качество, близкое к Real-ESRGAN, но позволяет проводить обучение на более слабой видеокарте за меньшее время. VDSR является самой простой моделью из трех вышеперечисленных, но, тем не менее, способна выполнять соизмеримое качество генерации при минимальных затратах ресурсов на обучение.

В дальнейшем качество моделей будет повышаться за счет увеличения объема обучающей выборки.

Таким образом, результаты данной работы имеют практическую значимость и могут быть применены в дальнейшем исследовании и совершенствовании существующих методов улучшения измеренных карт магнитного поля циклотронов для протонной терапии.

БЛИЖАЙШИЕ ПЛАНЫ И ПЕРСПЕКТИВЫ

1. Продолжение обучения моделей для изохронизации магнитного поля. Продолжение работы с моделями для достижения изохронности в магнитных полях — ключевой шаг в улучшении характеристик циклотронов. Для этого стоит усилить

подходы по обработке данных, оптимизировать архитектуру используемых моделей, а также ввести новые параметры для обучения на основе полученных данных.

2. Использование информации при оптимизации ВЧ-резонатора MSC230 для обучения моделей. Данные, полученные при оптимизации ВЧ-резонатора, можно использовать для создания более точных моделей, которые смогут предсказывать поведение резонатора для других типов циклотронов. Построение и обучение на этих данных может помочь в создании более эффективных предсказательных моделей, которые будут применяться при разработке новых ускорителей.

3. Обучение параметризованных моделей для расчетов магнитных каналов. Параметризованные модели уже применялись для расчетов магнитных каналов. Следует провести новое обучение с использованием последних данных, чтобы проверить, насколько эффективно эти модели могут адаптироваться к новым условиям и оптимизировать работу каналов.

4. Разработка подходов для применения ИИ в управлении источниками ионов. Подходы с использованием ИИ для управления ионными источниками могут значительно повысить эффективность работы системы. Рекомендуется исследовать возможности применения алгоритмов машинного обучения для управления параметрами ионного источника в режиме реального времени, а также провести испытания на стенде.

5. Тестирование и генерация идей для создания оптимального циклотрона. Этот этап позволит исследовать различные конфигурации, оценивать их эффективность и выявлять лучшие решения для улучшения характеристик ускорителя.

ЗАКЛЮЧЕНИЕ

Проектирование и оптимизация циклотронов требуют тщательного учета множества взаимозависимых параметров. Применение ИИ в проектировании и эксплуатации циклотронов уже приносит значительные результаты, помогая ускорить процесс разработки, улучшить управление и повысить надежность этих сложных систем. Методы искусственного интеллекта обладают потенциалом революционизировать процесс разработки и оптимизации циклотронов. Благодаря возможностям ИИ исследователи могут упростить проектирование, рассматривать более широкий спектр вариантов и улучшить общую производительность устройств.

СПИСОК ЛИТЕРАТУРЫ

1. *Calabretta L., Seidel M.* 50 Years of Cyclotron Development // IEEE Trans. Nucl. Sci. 2016.
2. <https://www.ptcog.ch/index.php/facilities-in-operation>.
3. *Meier E.* Artificial Intelligence Systems for Electron Beam Parameters Optimization at the Australian Synchrotron Linac // Proc. IPAC'10, Kyoto, Japan, 2010; <https://accelconf.web.cern.ch/IPAC10/papers/tupec025.pdf>.
4. *John J. St. et al.* Real-Time Artificial Intelligence for Accelerator Control: A Study at the Fermilab Booster // Phys. Rev. Accel. Beams. 2021. V. 24. P. 104601.
5. *Kong Y.B., Hur M.G., Lee E.J., Park J.H., Park Y.D., Yang S.D.* Predictive Ion Source Control Using Artificial Neural Network for RFT-30 Cyclotron // Nucl. Instr. Meth. 2016. V. 806. P. 55–60.

6. *Peng H. et al.* Recent Advancements of Artificial Intelligence in Particle Therapy. 2022.
7. *Mohamadian M., Afarideh H., Ghergherehchi M.* Optimized Feed-Forward Neural-Network Algorithm Trained for Cyclotron-Cavity Modeling // *Chin. Phys. C.* V. 41. 017003.
8. *Edelen A., Neveu N., Frey M., Huber Y., Mayes C., Adelman A.* Machine Learning for Orders of Magnitude Speedup in Multiobjective Optimization of Particle Accelerator Systems. arXiv:1903.07759.2020.
9. *Winklehner D. et al.* Order-of-Magnitude Beam Current Improvement in Compact Cyclotrons // *New J. Phys.* 2022. V. 24. 023038.
10. *Koser D., Waites L., Winklehner D., Frey M., Adelman A., Conrad J.* Input Beam Matching and Beam Dynamics Design Optimizations of the IsoDAR RFQ Using Statistical and Machine Learning Techniques // *Front. Phys.* 2022. V. 10. P. 875889.
11. *Bellotti R., Boiger R., Adelman A.* Fast, Efficient and Flexible Particle Accelerator Optimization Using Densely Connected and Invertible Neural Networks. arXiv:2107.00060v1 [physics.acc-ph].
12. *Karamyshev O. et al.* Research and Development of the SC230 Superconducting Cyclotron for Proton Therapy // *Phys. Part. Nucl. Lett.* 2021. V. 18, No. 1. P. 63–74.
13. *Xintao Wang, Ke Yu, Shixiang Wu, Jinjin Gu.* ESRGAN: Enhanced Super-Resolution Generative Adversarial Networks. arXiv:1809.00219v2.
14. *Ze Liu, Yutong Lin, Yue Cao, Han Hu.* Swin Transformer: Hierarchical Vision Transformer Using Shifted Windows. arXiv:2103.14030v2.
15. *Jiwon Kim, Jung Kwon Lee, Kyoung Mu Lee.* Accurate Image Super-Resolution Using Very Deep Convolutional Networks. arXiv:1511.04587v2.

Получено 28 октября 2024 г.